



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

DETEKCE JÍZDY NA ČERVENOU

DETECTION OF RED-LIGHT VIOLATION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

MILAN ŠORF

VEDOUcí PRÁCE

SUPERVISOR

Ing. JAKUB ŠPAÑHEL

BRNO 2017

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2016/2017

Zadání bakalářské práce

Řešitel: **Šorf Milan**

Obor: Informační technologie

Téma: **Detekce jízdy na červenou**
Detection of Red-Light Violation

Kategorie: Zpracování obrazu

Pokyny:

1. Prostudujte základy zpracování obrazu. Zaměřte se zejména na problematiku detekce statických i dynamických objektů v obraze.
2. Vyberte vhodnou metodu a navrhnete možný způsob řešení daného problému.
3. Experimentujte s vaší implementací a případně navrhnete vlastní modifikace metod.
4. Porovnejte dosažené výsledky a diskutujte možnosti budoucího vývoje.
5. Vytvořte stručný plakát nebo video prezentující vaši bakalářskou práci, její cíle a výsledky.

Literatura:

- S. R. E. Datondji, Y. Dupuis, P. Subirats and P. Vasseur, "A Survey of Vision-Based Traffic Monitoring of Road Intersections," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 10, pp. 2681-2698, Oct. 2016.
- Dále dle pokynů vedoucího.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění prvních tří bodů zadání.

Podrobné závazné pokyny pro vypracování bakalářské práce naleznete na adrese

<http://www.fit.vutbr.cz/info/szz/>

Technická zpráva bakalářské práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap (20 až 30% celkového rozsahu technické zprávy).

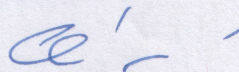
Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Špaňhel Jakub, Ing.**, UPGM FIT VUT

Datum zadání: 1. listopadu 2016

Datum odevzdání: 17. května 2017

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta informačních technologií
Ústav počítačové grafiky a multimédií
602 00 Brno, Božetěchova 2



doc. Dr. Ing. Jan Černocký
vedoucí ústavu

Abstrakt

Tato práce se zabývá automatickou detekcí jízdy na červenou ze statické kamery. Teoretická část práce popisuje princip detekce, představuje některé metody zpracování obrazu pro detekci semaforů a automobilů a popisuje metriky pro jejich srovnávání. Práce se rovněž zabývá implementací aplikace pro porovnání úspěšnosti jednotlivých metod.

Abstract

This thesis is focused on automatic detection of red-light violation using static camera. Theoretical part of the thesis describes the principle of detection and introduces various methods of detecting traffic lights and cars as well as their reliability metrics. The thesis also illustrates implementation of the application for evaluation of these methods.

Klíčová slova

jízda na červenou, detekce, semafor, křižovatka, rozdíl snímků, odečítání pozadí, OpenCV, Python

Keywords

red-light violation, detection, traffic light, traffic junction, frame difference, background subtraction, OpenCV, Python

Citace

ŠORF, Milan. *Detekce jízdy na červenou*. Brno, 2017. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Špaňhel Jakub.

Detekce jízdy na červenou

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Ing. Jakuba Špaňhela. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....

Milan Šorf
10. května 2017

Poděkování

Děkuji svému vedoucímu Ing. Jakubu Špaňhelovi za odborné vedení a čas, který této práci věnoval.

Obsah

1 Úvod	2
2 Základní obrazové transformace	3
2.1 Barevný model	3
2.2 Obrazové transformace	4
3 Přehled současných řešení	10
3.1 Detekce semaforu	10
3.2 Detekce vozidel	10
3.3 Společné metody	10
4 Detekce semaforů	12
4.1 Semafor	12
4.2 Metody detekce	13
4.3 Určení stavu semaforu	18
5 Detekce aut	19
5.1 Detekce pohybujících se objektů	19
5.2 Sledování vozidel	23
6 Odhad zastavovací čáry	24
6.1 Odhad podle krajnice	24
6.2 Odhad podle jízdní dráhy	25
6.3 Odhad podle směru jízdy	27
7 Detekce jízdy na červenou	28
8 Implementace programu a experimenty	30
8.1 Implementované programy	30
8.2 Použité algoritmy	30
8.3 Experimenty	30
9 Závěr	34
Literatura	35
Přílohy	37
A Obsah DVD	38
B Vliv osvětlení na jednotlivé metody	39

Kapitola 1

Úvod

Silniční doprava se v dnešní době týká prakticky každého člověka, ať už se jí účastní jako řidič, spolucestující, nebo jen jako chodec. I přes to, že je silniční doprava celosvětově nejvyužívanějším způsobem osobní dopravy a má i většinový podíl v nákladní dopravě, největší podíl na vzniku nehod má stále lidská chyba. Velká část z těchto nehod je způsobena bezohlednou a agresivní jízdou řidičů nedodržujících pravidla silničního provozu. Kontrolovat dodržování většiny těchto pravidel je pro člověka jednoduchý úkol, ale obrovské množství vozidel nacházející se na silnicích v každou denní dobu neumožňuje hlídat ani kritická místa jako jsou křižovatky nebo silnice vedoucí kolem škol, a to ani za použití dopravních kamer.

Jednou z možností řešení tohoto problému je využití automatizovaných systémů detekujících přestupky jako rychlou jízdu nebo jízdu na červenou. Klíčovou schopností takových systémů je automatická kalibrace, která je nezbytná při globálním nasazení takových systémů, kdy není možné každé zařízení po instalaci ručně kalibrovat. Tato práce se zaměřuje na automatickou detekci jízdy na červenou, jejím cílem je vytvořit program provádějící tuto detekci a experimentovat s různými metodami nalezení semaforu ve videu.

Kapitola 2 popisuje reprezentaci obrazu a základní transformace obrazu použité pro detekci. Kapitola 3 je krátkým přehledem některých v současnosti používaných metod ze kterých tato práce vychází. V kapitole 4 jsou popsány jednotlivé metody detekce semaforů a kapitola 5 se věnuje detekci automobilů. V kapitole 6 je popsán odhad zastavovací čáry. Následující kapitola 7 popisuje samotný proces detekce jízdy na červenou. Kapitola 8 popisuje implementaci programu a představuje výsledky experimentů na sadě testovacích video sekvencí.

Kapitola 2

Základní obrazové transformace

Obrazová data mohou být reprezentována pomocí vektoru, kde jsou popsána matematickou funkcí, nebo pomocí rastru. Jelikož přístroje pro tvorbu záznamů jako kamery a fotoaparáty využívají rastrovou reprezentaci obrazu, věnuje se tato práce jenom té. Zpracování obrazu je tvořeno dvěma kroky. Prvním z nich je převod obrazu reálného světa do digitální podoby vhodné pro počítačové zpracování, druhým krokem je samotné zpracování využívající například níže popsaných transformací. Informace o reprezentaci obrazu v této kapitole jsou čerpány z knihy Moderní počítačová grafika [15].


2.1 Barevný model

Barevný model popisuje základní barvy a způsob jejich míchání do výsledné barvy tak, aby co nejvěrněji napodobil zobrazovanou barvu. Jednotlivé modely jsou kompromisem mezi přesností napodobení barvy a složitostí daného modelu.

V praxi nejpoužívanějším barevným modelem je model RGB. Barva vzniká aditivním mícháním tří základních složek – červené (R), zelené (G) a modré (B). Počet odstínů barev závisí na množství bitů použitých pro kódování. Nejčastěji jsou pro kódování používány 3 bity, kde je každá barva reprezentovaná 8 bity. Tento způsob reprezentace umožňuje rozlišit celkem $2^8 \times 2^8 \times 2^8 = 16\,777\,216$ barev. Tento model zanedbává vliv osvětlení na barvu, proto je pro detekci obtížně použitelný. Místo něj byl použit model HSV, který pro reprezentaci barvy používá následujících hodnot:

- **Hue (H)** – odstín barvy, měří se jako poloha na barevném kole ($0^\circ - 360^\circ$).
- **Saturation (S)** – sytost barvy, měří se jako příměs šedé v procentech.
- **Value (V)** – jas, množství bílého světla měřené v procentech.

Tento model je více odolný vůči problémům způsobeným změnou osvětlení, jak dokládá obrázek 2.1.



Obrázek 2.1: Citlivost modelů RGB a HSV na osvětlení

2.2 Obrazové transformace

Obecně každé video je zatíženo šumem, který snižuje výkon detekčních algoritmů. Příčinami vzniku šumu jsou například nežádoucí odlesky, prudké změny osvětlení a stíny, nebo samotné vnitřní šumy kamery a nedostatečné zaostření. Při detekci jízdy na červenou je nutné uvažovat i o vlivech počasí jako dešť nebo sních, a o velkých změnách osvětlení v průběhu dne. Použitím transformací se snižuje vliv šumu na detekční algoritmus a vstupní snímky se připravují na další zpracování.

Převod do odstínů šedi

Detekce objektů ve videu je výkonostně náročný proces, zvláště má-li probíhat v reálném čase na videu o vysokém rozlišení. Jednou z metod snížení náročnosti je převod obrazu do odstínů šedi, kdy je každý bod reprezentován jedním bitem, a může tak nabývat 256 různých hodnot. Výsledek takového převodu ukazuje obrázek 2.2. Detekční algoritmus tak nemusí procházet tři hodnoty barvy pro každý bod, ale stačí provést jeden průchod.

Lidské oko vnímá intenzitu barevných složek různým způsobem, nejcitlivější je na zelenou barvu. Intenzita se pro každý bod vypočítá pomocí empiricky odvozeného vztahu (2.1):

$$I = 0.299R + 0.587G + 0.144B, \quad (2.1)$$

kde R , G a B jsou hodnoty červené, zelené a modré složky daného bodu.




Obrázek 2.2: Převod do odstínů šedi

Prahování

Prahování (*Thresholding*) je operace převodu obrazu o více jasových úrovních na obraz obsahující pouze dvě jasové úrovně. Prahování probíhá podle vztahu (2.2):

$$f(x) = \begin{cases} L & \text{pro } x < \tau \\ H & \text{pro } x \geq \tau, \end{cases} \quad (2.2)$$

kde τ je práh a L a H jsou výstupní hodnoty. Všechny hodnoty s intenzitou menší než τ jsou nahrazeny hodnotou L , hodnoty s intenzitou vyšší a rovnou práhu jsou nahrazeny hodnotou H . Ukázka takového převodu je na obrázku 2.3.



Obrázek 2.3: Ukázka prahování

Rozmazání

Rozmazání slouží k odstranění šumu v obraze. Dochází k zahmlení hran a prudkých přechodů v obraze, zvyšuje se tak přesnost operací otevření a uzavření. Ukázka je na obrázku 2.4.

Základním principem rozmazání je úprava každého bodu v závislosti na bodech v jeho okolí. Nejjednodušším způsobem je prosté zprůměrování hodnot okolních bodů, případně

zohlednění vzdálenosti od zpracovávaného bodu. Nejpoužívanější možností je *Gaussovo rozmazání*, které využívá Gaussovu funkci.



Obrázek 2.4: Ukázka rozmazání

Eroze

Eroze je proces odstranění samostatných bodů, které bývají většinou zapříčiněné šumem a narušují další průběh detekce.


Při erozi je postupně na každý bod v popředí obrazu pohlíženo jako na střed předem určené matice jádra, pokud každý bod v takto umístěném jádru překrývá bod na původním obrázku, je bod ponechán, jinak je odstraněn.

Erozi je možné použít i k oddělení objektů dotýkajících se okraji. Nevýhodou eroze je narušení tvaru okraje objektu, to je možné částečně kompenzovat aplikací dilatace.

Dilatace

Dilatace pracuje na stejném principu jako eroze, ale prochází body v pozadí obrazu a pokud je pod maticí alespoň jeden bod obrazu, přidává zkoušený bod do popředí. To má za následek růst objektů a zaplnění drobných děr.

Následující obrázky ukazují princip (2.5) a ukázkou (2.6) transformace s jádrem o rozměrech 3×3




Obrázek 2.7: Parametrický popis přímky

Pokud do rovnice (2.3) dosadíme souřadnice libovolného bodu (x_i, y_i) , pak množina všech řešení (ρ, θ) vzniklé rovnice (2.4):

$$x_i \cos \theta + y_i \sin \theta = \rho, \quad (2.4)$$

tvoří v Houghově prostoru spojitou křivku. Po promítnutí všech bodů nějaké přímky do tohoto prostoru se křivky odpovídající těmto bodům protnou v jediném bodě $(\rho_{max}, \theta_{max})$. Tato dvojice jsou hledané parametry přímky. Ukázka je na obrázku 2.8.



Obrázek 2.8: Ukázka detekce přímky – původní obrázek, příslušný Houghův prostor a nalezená přímka

Detekce kružnic

Po provedení několika změn je možné tuto transformaci využít pro detekci kružnic. V tom případě se vychází z rovnice (2.5):

$$(x - a)^2 + (y - b)^2 = c^2, \quad (2.5)$$

kde a, b reprezentují střed kružnice a c její poloměr.

Každý bod není transformován do přímky jako při hledání přímek, ale do kuželu popsaného rovnicí (2.6):

$$(x_i - a)^2 + (y_i - b)^2 = c^2. \quad (2.6)$$

Algoritmus nyní hledá tři parametry, proto je výrazně výpočetně náročnější. Vzhledem k jeho náročnosti ho nelze použít pro detekci kružnic v celém snímku v reálném čase, je proto nutné omezit prohledávaný prostor. Obrázek 2.9 představí výsledek detekce kružnic.



Obrázek 2.9: Ukázka detekce kružnic. Metoda je velice náročná, zvláště při neznámé velikosti hledaných kružnic. Velké problémy způsobují brzdová světla stojících vozidel. Pro použití v reálném čase je nutné radikální omezení prohledávané části obrazu.

Kapitola 3

Přehled současných řešení

Tato kapitola představuje neúplný přehled v současnosti používaných řešení. Ta spadají do dvou hlavních kategorií – řešení využívající k detekci pouze informací získaných z aktuálního videa a řešení využívající strojového učení na množství předem připravených vzorků.

3.1 Detekce semaforu

Většina přístupů k detekci semaforu spadá do jedné ze dvou kategorií – *detekce podle barev* nebo *detekce podle tvaru*.

Detekce podle barev

Metody detekce podle barev převádí obraz do vhodného barevného modelu a poté hledají odpovídající barvy. Příkladem je publikace [8], která řeší detekci semaforu hledáním červených, žlutých a zelených barev v obraze. Tato práce řeší i detekci zastavovací čáry hledáním bílé barvy v obraze.

Detekce podle tvaru

Tento způsob detekce je založený na hledání daných tvarů v obraze.

Práce [11] začíná detekci nalezením rámců semaforu pomocí detekce obdélníků, poté určuje jednotlivá světla detekcí kruhů. V publikaci [3] probíhá detekce po odhadu podle barev hledáním elips, což umožňuje detekovat i poškozená nebo částečně zakrytá světla která nemají tvar kruhu. Práce [12] opět začíná detekcí podle barev, dalším krokem je detekce hran, ze kterých jsou poté sestaveny semaforey.

3.2 Detekce vozidel

Podle kompilace prací [7] je pro detekci ve většině případů použita některá z variant *odečítání pozadí*. Tato práce implementuje metodu detekce vozidel využívající rozdíl snímků založenou na práci [10] a detekci odečítáním pozadí vycházející z publikace [4].

3.3 Společné metody

Následující metody lze využít pro detekci semaforů i vozidel.

Neuronové sítě

Neuronová síť je modelem biologických struktur neuronů v živých organismech se schopností se učit.

Síť je předloženo množství obrázků a informace zda se na daném obrázku nachází hledaný objekt, ta upravuje svoje chování tak, aby dosáhla co nejvyšší úspěšnosti. Vzhledem k podobnosti jednotlivých automobilů a téměř totožnému vzhledu semaforů lze k jejich rozpoznávání s úspěchem použít neuronových sítí. Využití neuronové sítě pro detekci vozidel popisuje práce [6], detekcí semaforů se zabývá publikace [13].

Kaskáda klasifikátorů

Detekce probíhá pomocí soustavy klasifikátorů s postupně narůstající přesností (a složitostí). Rychlé klasifikátory snižují množství dat procházející k jejím náročnějším následníkům, pokud objekt projde celou kaskádou, je prohlášen za hledaný objekt. Tento způsob detekce představuje práce [14].

Random Forest

Z množiny testovacích dat jsou náhodně vybírány vzorky a vlastnosti pro tvorbu stromu, opakováním tohoto postupu vzniká množina rozhodovacích stromů. Konečný výsledek je určen kombinací rozhodnutí všech stromů. Výhodou nad jedním rozhodovacím stromem je větší přesnost.

V následujících kapitolách budou blíže představeny metody implementované v této práci.

Kapitola 4

Detekce semaforů

Tato kapitola se věnuje procesu detekce semaforu z videa. Začíná stručným popisem semaforů, dále pak představuje jednotlivé metody použitelné pro jejich rozpoznání.

4.1 Semafor

Světelné signalizační zařízení, tzv. *semafor* je zařízení sloužící k řízení provozu na pozemních komunikacích pomocí světelných signálů. Nacházejí se zejména na křižovatkách, přechodech pro chodce, železničních přejezdech, nebo v jízdních pruzích se střídavým provozem. Pozice semaforů u silnic ilustruje obrázek 4.1.



Obrázek 4.1: Různé umístění semaforů u silnic – semafor se vždy nachází v různé výšce vedle silnice, v některých případech je doplněn i semaforem nad silnicí.

Semafor rozlišuje tyto hlavní stavy [1]:

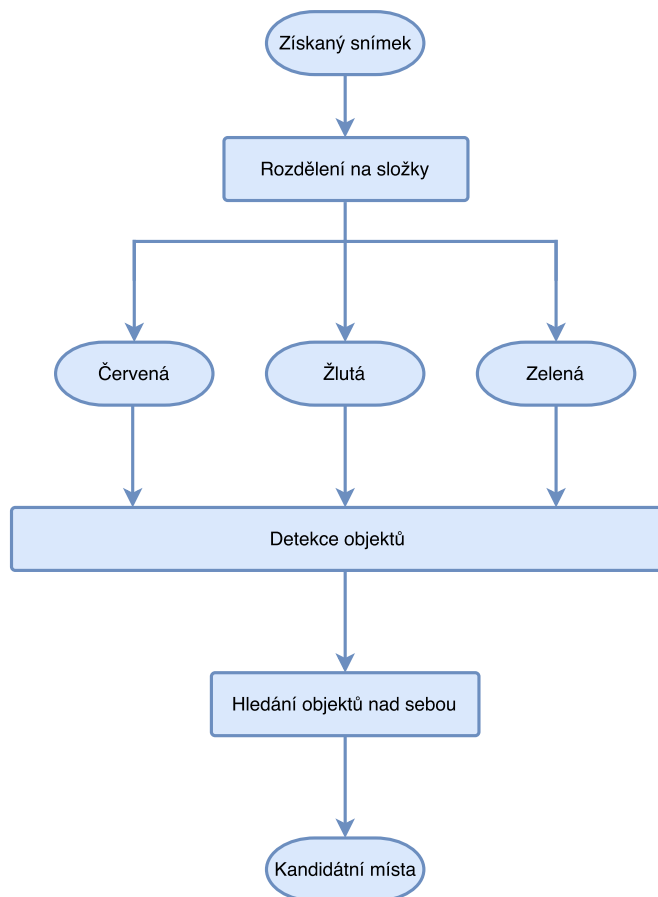
- **Stůj!** – Svítí červené světlo, auta mají zastavit před semaforem.
- **Pozor!** – Svítí současně červené a žluté světlo, řidiči se mají připravit k jízdě.
- **Volno!** – Svítí zelené světlo, auta mohou pokračovat v jízdě.
- **Pozor!** – Svítí žluté světlo, pokud auta stihnou bezpečně zastavit, mají to udělat.

4.2 Metody detekce

Následující část popisuje různé způsoby detekce semaforů použité v této práci. Cílem detekce je odhalit všechna kandidátní místa ve kterých se může nacházet semafor.

Detekce podle barvy

Nejjednodušší metoda detekce semaforu, pracuje na principu hledání předem určených barev v obraze. Její schéma je představeno na obrázku 4.2.



Obrázek 4.2: Schéma detekce podle barvy – metoda pracuje se třemi kopiemi snímku, pro každou z nich vytvoří masku obsahující pouze body v barevném rozsahu dané barvy semaforu a v ní hledá objekty vhodné velikosti. Složením nálezů ze všech variant barev vzniká výsledné kandidátní místo.

Při přípravě této metody byla určena průměrná hodnota barev červeného, žlutého a zeleného světla semaforu z 10 testovacích záběrů. Na základě experimentů byly určeny rozsahy α , β a γ v okolí těchto průměrných barev.

Detekce začíná procházením snímků. To probíhá po dobu několika minut, aby byly na testovaných snímcích zachyceny všechny barvy semaforu. Z každého snímku je vytvořena maska obsahující pouze body v barevném rozsahu pro každý z prahů α , β , γ .


Na těch probíhá detekce všech objektů, pokud se podíl výšky a šířky objektu blíží 1 (může se jednat o kruh), jsou souřadnice objektu uloženy do seznamu možných světél dané barvy. Výsledky této detekce jsou znázorněny na obrázcích 4.3, 4.4 a 4.5.



Obrázek 4.3: Detekce červené barvy



Obrázek 4.4: Detekce žluté barvy



Obrázek 4.5: Detekce zelené barvy

Po skončení procházení snímků se porovnají seznamy možných světél a každá kombinace všech tří barev nacházejících se nad sebou ve správném pořadí je prohlášena za kandidátní místo. Výsledek detekce je na obrázku 4.6.



Obrázek 4.6: Detekované pozice světél na nalezeném semaforu

Zelené světlo je méně výrazné a kolem silnic se nachází velké množství zelené barvy, proto je při problémech s nalezením zeleného světla možné tvořit kandidátní místo jen z červené a žluté barvy a odhadnout pod nimi čtverec podobný jejich velikosti.

Detekce podle rámu

Tato metoda vychází z metody detekce podle barev, pokouší se na základě barvy určit rám semaforu, ten potom rozdělí na třetiny a prohlásí za kandidátní místo. Metoda pracuje s jediným snímkem a proto je v porovnání s ostatními extrémně rychlá a nenáročná. Je schopná detekovat i semaforey u kterých detekce podle barvy neuspěje, ale zároveň tvoří velké množství falešně pozitivních nálezů. Ukázka následuje na obrázku 4.7.




Obrázek 4.7: Detekce rámu semaforů. Metoda se pokouší nalézt na jednom snímku objekty odpovídající barvou a tvarem rámu semaforu. Cílem není nalezení semaforů, ale rychlá redukce prohledávaného prostoru pro náročnější metody.

Tato metoda často detekuje jen tmavou část semaforu, není proto vhodná pro samostatné použití, ale je jednoduchým způsobem jak omezit prohledávaný prostor pro některé náročnější metody.

Detekce podle tvaru

Tato metoda pracuje na základě detekce kruhových objektů.

Detekce kruhů probíhá pomocí Houghovy transformace popsané výše. Tato metoda je velice náročná, proto je vhodné ji provádět jenom po předchozím omezení prohledávaných míst. Dalším problémem je detekce poškozených nebo částečně zakrytých světel které nemají kruhový tvar. Ukázka nalezených kruhů je na obrázku 4.8.




Obrázek 4.8: Detekce kruhů

Detekce podle chování

Tato metoda nepracuje s barvou ani tvarem světel, řeší tak některé problémy předchozích metod.

Hledá ve videu trojice objektů umístěných nad sebou, které postupně procházejí všemi běžnými stavy semaforu (viz. obrázek 4.9). Hledání probíhá pomocí odečítání snímků. Metoda hledá v rozdílech snímků tři nad sebou umístěné tvary přibližně stejné velikosti jejichž poměr výška : délka se blíží hodnotě 1.



Obrázek 4.9: Stavy semaforu

Tuto metodu je možné urychlit kombinací s metodou detekce podle rámu pro urychlení zpracování.

4.3 Určení stavu semaforu

Po nalezení kandidátních míst je každé považováno za jeden semafor a je pro něj zahájena trénovací fáze. Během té je pro každé světlo na základě průměrné barvy jeho oblasti určena očekávaná hodnota pro svítící a zhasnuté světlo, ty jsou poté použity k určování stavu podle tabulky 4.1.

Pokud semafor vykáže neočekávaný stav nebo má nějaké jeho světlo barvu mimo očekávání, je z dalšího pozorování vyřazen. Stav nalezených semaforů je ve videu znázorněn barvou jejich rámu, viz. obr. 4.10.

Červená	Žlutá	Zelená	Stav semaforu
ANO			Stát
ANO	ANO		Připravit
		ANO	Jet
	ANO		Brzdit

Tabulka 4.1: Validní stavy semaforu



Obrázek 4.10: Znázornění detekovaných stavů

Kapitola 5

Detekce aut

Tato kapitola se věnuje popisu detekce projíždějících automobilů. Základem je detekce pohybujících se objektů, pro kterou byly použity dva přístupy – *odečítání pozadí* a *rozdíl snímků*. Dalším úkolem je sledování aut napříč videem.

5.1 Detekce pohybujících se objektů

Cílem detekce pohybu v obraze je nalézt místa, která se liší od minulého snímku a určit, zda se skutečně jedná o pohybující se objekty nebo o šum způsobený změnami v okolí (odlesky, změna osvětlení atp.).

Rozdíl snímků


Tato metoda pracuje pouze na principu odečtení dvou posledních snímků. Je výrazně jednodušší a rychlejší, také je velmi citlivá na šum a změny osvětlení. Kvůli citlivosti je využita v algoritmu detekce semaforu podle vzoru chování. Ukázka je na obrázku 5.1.

Oba snímky jsou převedeny do odstínů šedi, poté jsou porovnány podle vzorce (5.1):

$$|P[F(t)] - P[F(t+1)]| > \tau, \quad (5.1)$$

kde $P[F(t)]$ je snímek, $P[F(t+1)]$ je následující snímek a τ je práh pro rozdíl snímků.

Pokud jsou ve výsledném obraze nalezeny dostatečně velké objekty, jsou prohlášeny za automobily.



Obrázek 5.1: Nalezené rozdíly mezi dvěma snímky

Cílem detekce jízdy na červenou není přesně detekovat tvar auta, stačí detekovat pohyb relativně velkého objektu při stavu semaforu „Stůj!“, proto je tato metoda vhodným způsobem snížení náročnosti pro provádění detekce v reálném čase. Po úspěšné detekci je možné použít na několikavteřinový úsek videa s přestupkem komplexnější algoritmy pro rozpoznání aut jedoucích v těsné blízkosti nebo přečtení poznávací značky.

Odečítání pozadí

Metoda odečítání pozadí (*Background subtraction*) je jednou ze základních metod detekce pohybu v obraze. Postupně po jednotlivých bodech odečítá snímek od referenčního snímku pozadí. Existuje velké množství algoritmů pro odečítání pozadí, podle publikace [4] mají všechny stejnou základní strukturu:

- **Předzpracování** (*pre-processing*) – Úprava vstupu do tvaru vhodnějšího pro další zpracování.
- **Modelování pozadí** (*background modeling*) – Tvorba statistického popisu pozadí.
- **Detekce popředí** (*foreground detection*) – Tvorba masky pixelů které neodpovídají modelu.
- **Ověřování dat** (*post-processing*) – Zpřesnění a kontrola vytvořené masky.

Předzpracování

Při předzpracování se snímky převádí do vhodného barevného modelu a použitím filtrů se redukuje šum v obraze. Filtrů pro vyhlazení se využívá i pro redukci vlivu počasí, jako je sněžení nebo déšť. Klíčovou částí předzpracování pro systémy pracující v reálném čase je snížení rozlišení a snímkovací frekvence vstupu, dochází tak ke zvýšení výkonu algoritmu.

Modelování pozadí

Cílem modelování pozadí je vytvořit model odolný vůči změnám v pozadí, ale zároveň schopný identifikovat všechny pohybující se objekty. Modelování dělíme podle času tvorby modelu na *statické* a *dynamické*.

Při statickém modelování je model pozadí určen v trénovací fázi před samotnou detekcí a v průběhu detekce se nemění, dochází tak ke snížení nároků na výkonnost. Model je vytvořen ze sekvence snímků bez pohybujících se objektů. Nevýhodou tohoto přístupu je neschopnost reagovat na postupné změny jako například změny osvětlení v průběhu dne.

Při dynamickém modelování je model v průběhu detekce upravován, což umožňuje lepší reakci na postupné změny za cenu vyšší výpočetní náročnosti. Nevýhodou je vznik „duchů“ v místě delší dobu nehybného objektu který se opět začne pohybovat.

Modelování se dále dělí podle techniky výpočtu modelu na *rekurzivní* a *nerekurzivní*.

Nerekurzivní techniky

Nerekurzivní techniky používají zásobník, ve kterém uchovávají N posledních snímků. Model pozadí je určen podle aktuální variace snímků ze zásobníku, není tak ovlivněn staršími změnami. Nevýhodou těchto metod mohou být požadavky na paměť. Tvorba modelu probíhá například odečítáním posledních dvou snímků, nebo výpočtem průměru nebo mediánu posledních N snímků.

Rekurzivní techniky

Rekurzivní techniky nepoužívají zásobník, model pozadí je rekurzivně aktualizován pro každý další snímek a odráží se v něm tak všechny dosud zpracované snímky. Výhodou těchto technik je nižší paměťová náročnost. Příkladem rekurzivních technik jsou například Klouzavý průměr (*Running average*), Klouzavý Gaussův průměr (*Running Gaussian average*) rozšiřující Klouzavý průměr o Gaussovo rozložení pravděpodobnosti, nebo Směsice Gaussových křivek (*Mixture of Gaussians*, *MOG*), popsána v publikaci [5].

Klouzavý průměr

Model pozadí je rekurzivně aktualizován podle vztahu (5.2):

$$B_t + 1(x, y) = \alpha I_t(x, y) + (1 - \alpha) B_t(x, y), \quad (5.2)$$

kde $\alpha \in (0, 1)$ je konstanta určující míru vlivu vstupního snímku $I_t(x, y)$ na model pozadí $B_t + 1(x, y)$, x a y jsou souřadnice daného bodu.

Vyšší hodnoty α způsobují rychlejší adaptivitu modelu, nižší hodnoty stabilnější model méně náchylný na změny v obraze. Hodnota α je typicky v rozsahu (0.005; 0.1)

Detekce popředí

V této fázi dochází k porovnání aktuálního snímku s modelem pozadí ve snaze určit kandidáty na popředí. Pixel je označen jako kandidát na popředí, pokud platí (5.3):

$$|I_t + (x, y) - B_t(x, y)| > \tau, \quad (5.3)$$

kde $I_t + (x, y)$ je bod aktuálního snímku, $B_t(x, y)$ je model pozadí a τ je předem určený práh.

Kvalita detekce závisí na vhodně zvoleném prahu, pokud je zvolená hodnota příliš nízká, jsou detekovány i části pozadí. Pokud je naopak příliš vysoká, dochází pouze k částečné detekci popředí. Lepší metody používají zvláštní hodnotu prahu pro každý pixel, tyto hodnoty jsou navíc aktualizovány v průběhu detekce.


Ověřování dat

Při ověřování probíhá kontrola masky vytvořené v předchozích krocích. Dochází k odstranění samostatných bodů pomocí morfologických operací jako eroze a dilatace, následně dochází k tvorbě blobů (množiny spojených bodů), které korespondují s reálnými objekty. Příliš malé bloby jsou odstraněny.

5.2 Sledování vozidel

Detekce jízdy na červenou musí probíhat jenom v jízdním pruhu vedoucím k semaforu, proto je nutné každé auto poznat na více snímcích, aby bylo možné určit směr jeho jízdy.

Výstupem detekce pohybujících se objektů jsou jejich souřadnice (viz. obr. 5.2), na jejich základě probíhá další identifikace.



Obrázek 5.2: Výsledek detekce objektů v pohybu. Po nalezení každého objektu jsou uloženy souřadnice obdélníků zvýrazněných na obrázku, těch je využito v další detekci.

Při první detekci jsou uloženy informace o pozici a barvě objektu, a je proveden odhad pozice objektu na dalším snímku. Prvotní odhad probíhá rozšířením detekované oblasti o 25% ve všech směrech, při nalezení objektu podobné barvy na očekávaném místě je porovnáním s předchozí pozicí určen směr pohybu a pro další odhad pozice je rozšíření provedeno pouze v daném směru, na základě vzdálenosti mezi předchozími místy detekce je upravována velikost a umístění odhadu další pozice objektu.

Pokud objekt není detekován, odhad se posouvá podle dosavadních informací, když není detekován na deseti po sobě jdoucích snímcích, předpokládá se že opustil záběr a je vyřazen ze zásobníku aut. Auta která směřují od semaforu nebo se k němu blíží zezadu jsou z dalšího procesu detekce vyřazena.

Kapitola 6


Odhad zastavovací čáry

Termín zastavovací čára v této práci označuje místo, na kterém už se vozidlo ignorující semafor dopouští přestupku. K detekci dochází pokud se v okamžiku kontaktu vozidla s touto čarou nachází semafor ve stavu „Stůj!“.

Tuto čáru není možné vzhledem ke stavu většiny silnic detekovat přímo ze záběru, proto je toto místo v každém videu odhadováno s použitím pozice semaforu. Odhad nemusí být přesný, slouží jako začátek pásma detekce jízdy na červenou. Základem odhadu jsou pozice semaforu a přímka reprezentující směr silnice vedoucí k semaforu. Zastavovací čára je potom kolmicí k této přímce procházející bodem na semaforu, vzhledem k pozici semaforu může být posunutá nahoru nebo dolů pro přesnější odhad. K nalezení přímky reprezentující směr silnice jsou použity následující metody:

6.1 Odhad podle krajnice


Tato metoda pracuje na základě určení krajnice v záběru. Krajnice je detekována tvorbou masky pro bílou barvu a následným hledáním dlouhých úzkých objektů v této masce, jak ukazuje obrázek 6.1.



Obrázek 6.1: Hledání krajnic podle bílé barvy

Pokud se semafor nachází mimo silnici, zastavovací čára je potom určena jako kolmice mezi krajnicí a semaforem, auto tak detekuje při průjezdu kolem semaforu. Pokud je semafor

nad silnicí, je čára posunutá dolů pro zvýšení přesnosti. Semafor nad silnicí je k tvorbě čáry použit jen v případě kdy není žádný semafor vedle silnice. Výsledek detekce je na obrázku 6.2.



Obrázek 6.2: Výsledek odhadu směru silnice vedoucí k semaforu na základě detekce krajnice. Fialová – odhadnutý směr silnice, červená – zastavovací čára.


Tato metoda je nepoužitelná v zimních měsících, kdy jsou silnice pokryté sněhem, a u silnic které krajnice nemají. Tyto situace se pokouší řešit následující metoda.

6.2 Odhad podle jízdní dráhy

Tato metoda se pokouší odhadnout silnici vedoucí k semaforu podle jízdní dráhy detekovaných vozidel, viz obr. 6.3 a 6.4.



Obrázek 6.3: Detekované dráhy vozidel




Obrázek 6.4: Odhadnutý směr silnice

Nevýhodou tohoto přístupu je zkreslení vznikající pokud většina aut v záběru jede jiným směrem. Algoritmus se tento problém snaží kompenzovat přidělením větší váhy vozidlům jedoucím ze spodní části obrazu, srovnání je na obrázcích 6.6 a 6.7. To vychází z předpokladu že pokud je v záběru viditelný semafor, silnice ke které patří musí vést ze spodní části obrazu

nezávisle na úhlu pod kterým je záběr pořízen, jak demonstruje obrázek 6.5. I s kompenzací algoritmus zaostává za detekcí podle krajnice, která přímo reprezentuje směr dané silnice, ale pro odhad zastavovací čáry jsou výsledky dostačující.



Obrázek 6.5: Bez ohledu na úhel záběru vyjíždějí vozidla jedoucí k semaforu vždy ze spodní části záběru.




Obrázek 6.6: Odhad směru silnice k semaforu bez kompenzace pro vozidla jedoucí jiným směrem. Fialová – odhadnutý směr jízdy, červená – zastavovací čára



Obrázek 6.7: Odhad s kompenzací


6.3 Odhad podle směru jízdy

Tato metoda předpokládá, že vozidla jedoucí k semaforu jedou relativně rovně. Na každém snímku jsou uloženy přímky reprezentující směry jízdy všech vozidel (viz obr. 6.8), ty jsou poté seskupeny podle úhlu který svírají se spodní hranou videa. Výhodou tohoto přístupu je zanedbání odbočujících vozidel a náhodných pohybů v záběru, při odhadu se používají jen nejmohutnější skupiny přímek.



Obrázek 6.8: Odhad směru jízdy jednotlivých vozidel

Nejmohutnější skupina přímek reprezentuje silnici, pokud druhá skupina obsahuje přibližně stejný nebo o něco menší počet přímek, dá se předpokládat že obě reprezentují silnice v záběru. V tom případě se pomocí srovnání úhlů obou skupin s úhlem nejnižší detekovaného vozidla v záběru určí silnice vedoucí k semaforu a druhá skupina přímek reprezentuje silnici za semaforem, ta se použije přímo k odhadu zastavovací čáry. V opačném případě je použita přímka silnice vedoucí k semaforu a odhad probíhá s pomocí semaforu jako u předchozích metod. Výsledek znázorňuje obrázek 6.9.



Obrázek 6.9: Směry silnic odhadnuté podle dráhy projíždějících vozidel. Zelená – silnice vedoucí k semaforu, červená – silnice za semaforem. Při nalezení dvou silnic je ta za semaforem použita jako zastavovací čára.

Kapitola 7

Detekce jízdy na červenou

Tato kapitola se věnuje popisu použitého algoritmu pro detekci jízdy na červenou. Samotná detekce probíhá ve dvou fázích, *přípravné* a *detekční*. Přípravná fáze začíná detekcí semaforů a kalibrací detektoru stavů pro každý semafor. V případě nalezení jednoho či více semaforů pokračuje příprava odhadem zastavovací čáry.

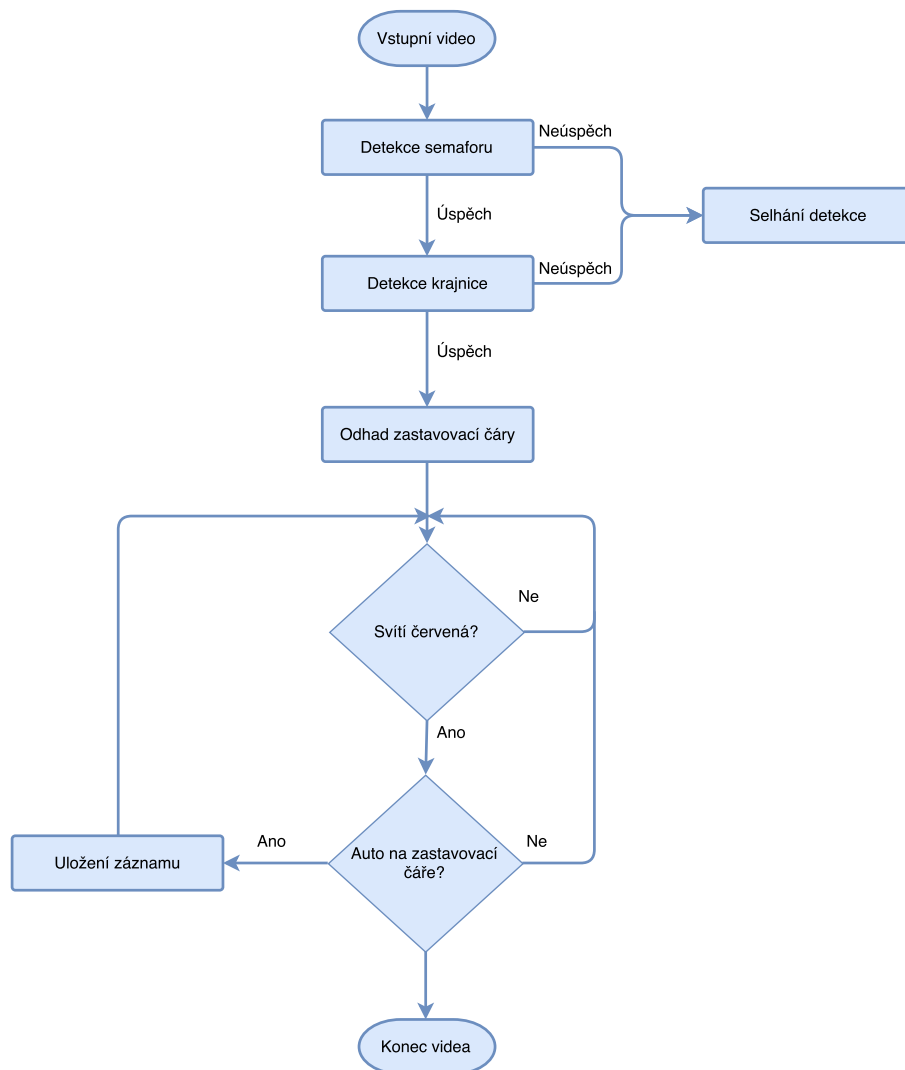
Po dokončení odhadu zastavovací čáry začíná detekční fáze. Pokud je semafor ve stavu „Stůj!“ a auto přijde do kontaktu se zastavovací čarou, je vytvořeno video obsahující 5 vteřin záznamu před detekcí a 2 vteřiny po ní s časem detekce v názvu souboru. Těchto videí je možné využít k dalšímu zpracování, jako detekci poznávací značky. Schéma celé detekce je na obrázku 7.1.

Po spuštění programu začíná přípravná fáze trvající první 3 minuty videa. Během těch se zpracovává pouze každý desátý snímek, tím je zajištěn skokový přechod barev na semaforu i u videí s vyšší snímkovou frekvencí a zároveň se zkracuje doba trvání příprav. Doba přípravné fáze byla empiricky určena tak, aby bylo zajištěno proběhnutí alespoň tří kompletních cyklů semaforu.

Během přípravné fáze sbírá zvolená metoda detekce semaforu kandidátní místa. Pro další zpracování jsou ponechány pouze duplikátní hodnoty, tím se vyloučí některá špatná kandidátní místa která se v obraze nacházejí jen jednou, např. náhodné odlesky nebo brzdomá světla.

Tvorba semaforu probíhá porovnáváním kandidátních míst, každá tři místa podobné velikosti nacházející se nad sebou jsou prohlášena za semafor. Pro každé světlo jsou určeny přibližné hodnoty barev „svítí“ a „nesvítí“, těch je využito k určení stavu semaforu. Pokud semafor vykazuje neplatné stavy, je ze seznamu semaforů odebrán.

Po tvorbě semaforů a odhadu zastavovací čáry začíná detekční fáze programu. Zvolená metoda detekce aut na každém snímku detekuje auta, pokud bylo podobné auto detekováno na předchozích snímcích, jsou upraveny informace o jeho poloze a směru jízdy. Pokud se auto jedoucí ve směru semaforu dotkne zastavovací čáry a semafor je ve stavu „Stůj!“, je uložen záznam (viz.obr. 7.2).



Obrázek 7.1: Schéma detekčního algoritmu



Obrázek 7.2: Okamžik detekce jízdy na červenou – přední stěna obdélníku detekovaného vozidla protíná zastavovací čáru za stavu semaforu „Stůj!“.

Kapitola 8

Implementace programu a experimenty

Pro implementaci programu pro detekci jízdy na červenou jsem využil knihovny pro zpracování obrazu OpenCV (*Open Source Computer Vision Library*) verze 3.1.0. Tato knihovna obsahuje více než 2500 algoritmů použitelných pro rozpoznávání tváře, identifikaci objektů v obraze, klasifikaci lidských akcí ve videu, zachycení pohybujících se objektů, extrahování 3D modelů, spojení více snímků do jednoho, nalezení shodných snímků v databázi nebo snímání pohybu očí a jiné. OpenCV je kompatibilní s programovacími jazyky C, C++, Java, Python a Matlab/Octave [9]. Výstupní videa jsou tvořena pomocí knihovny sk-video [2].

Z uvedených jazyků jsem zvolil Python ve verzi 3.5.2. Výsledné aplikace se nachází na přiloženém DVD (Příloha A).

8.1 Implementované programy

První přiložená aplikace slouží k demonstraci detekce jízdy na červenou, po spuštění vizualizuje detekované stavy semaforu v zadaném videu a při detekci jízdy na červenou vytvoří její záznam.

Druhá přiložená aplikace postupně otestuje všechny implementované metody detekce semaforu na testovacích videích a vytvoří statistiky o jejich úspěšnosti.

8.2 Použité algoritmy

Byly implementovány všechny výše popsané algoritmy, konkrétně:

- **Detekce semaforů** – podle barvy, podle rámu, podle tvaru, podle chování
- **Odhad zastavovací čáry** – podle krajnice, podle dráhy vozidel
- **Detekce pohybu** – odečítání pozadí, rozdíl snímků

8.3 Experimenty

Experimentální ověření výsledků bylo rozděleno do dvou částí – testování detekce semaforů a testování detekce vozidel.

Detekce semaforů

Pro účely testování detekce semaforů bylo pořízeno 100 záběrů křižovatek za různých podmínek, výsledky porovnání jednotlivých metod jsou shrnuty v tabulce 8.1. Byla měřena schopnost detekovat pozici semaforů v obraze, schopnost číst stavy detekovaných semaforů a přesnost detekce.

Metoda	Nalezených semaforů	Úspěšnost detekce
Detekce podle chování	185 / 185	100.00 %
Detekce podle rámu	90 / 185	48.64 %
Detekce podle barvy	18 / 185	9.72 %

Tabulka 8.1: Výsledky jednotlivých metod

Nejlepší detekční metodou je detekce podle chování s naměřenou úspěšností 100%. Metoda detekce podle tvaru vzhledem ke své náročnosti neprošla rozsáhlejším testováním, podpůrná detekce rámu pro její urychlení dosáhla pouze 46% úspěšnosti.

Největším problémem se ukázalo být zkreslení barev světel semaforů, při natáčení proti slunci nebo za tmy dochází i ke zkreslení tvarů světel, to způsobuje malou úspěšnost metod založených na detekci podle světla nebo tvaru.

Přesnost detekčních metod byla měřena metrikou IoU (*Intersection over Union*), která porovnává přesnost nalezení jednotlivých světel s jejich člověkem určenými pozicemi. Výsledky jsou uvedeny v tabulce 8.2.

Metoda	IoU – červená	IoU – oranžová	IoU – zelená
Detekce podle chování	61.58 %	9.40 %	19.00 %
Detekce podle rámu	11.12 %	11.12 %	11.12 %
Detekce podle barvy	85.71 %	4.69 %	23.76 %

Tabulka 8.2: Přesnost detekce jednotlivých metod

Metody detekují semafor hledáním svítících částí, proto se přesně neshodují s ručně zadanými daty. Vzhledem k výrazně lepším výsledkům v detekci červeného světla je možné zbytek semaforu korigovat podle jeho pozice.

Na přiloženém DVD se nachází 5 z použitých testovacích záběrů spolu s programem pro vytvoření statistik jejich úspěšnosti.

Detekce vozidel

Pro účely testování detekce vozidel bylo použito 10 záběrů křižovatek, testování proběhlo na křižovatkách s ideálním umístěním kamery tak, aby kamera umístěná nad silnicí sní-

mala všechny jízdní pruhy a vozidla se v záběru nepřekrývala, i křižovatkách snímaných z méně vhodných pozic (viz. obr. 8.1). Testování probíhalo v místě zastavovací čáry a za ní. Naměřené výsledky jsou uvedeny v tabulkách 8.3 a 8.4.



Obrázek 8.1: Vlevo ideální, vpravo nevhodné umístění kamery. Vozidla se při průjezdu překrývají a tím ztěžují detekci, větší vozidla v pruhu u kamery zakrývají zbytek silnice.

Metoda	Celkem aut	Červená	Oranžová	Zelená
Odečítání pozadí	2857	10	35	2812
Rozdíl snímků	2654	10	35	2609
Reálné hodnoty	1212	10	35	1167

Tabulka 8.3: Výsledky detekce na zastavovací čáře

Metoda	Celkem aut
Odečítání pozadí	1235
Rozdíl snímků	1230
Reálné hodnoty	1212

Tabulka 8.4: Výsledky detekce projíždějících vozidel

Největším problémem se ukázaly být kolony aut vznikající před semaforem, při jejich rozjezdu dochází k mnoha falešným detekcím. Tento problém má paradoxně menší dopady na detekci z nevhodně umístěných kamer, viz obr. 8.2.



Obrázek 8.2: Při rozjíždění kolony aut dochází k falešným detekcím, tento problém má menší dopad na nevhodně umístěnou kameru, kde v záběru zůstávají mezery mezi stojícími automobily.

I když nemá výše popsany problém vliv na detekci jízdy na červenou, znamená to že pro sbírání dalších statistik jako počet projíždějících aut je nutné vozidla detekovat znova v místě kterým jen projíždí, tabulka 8.4 ilustruje detekci vozidel v místě za zastavovací čarou.

Obě metody detekce vozidel jsou schopny detekovat většinu projíždějících vozidel, pokud se vozidla překrývají nebo jedou v těsné blízkosti, jsou detekována jako skupina. Tento výsledek je pro účely práce dostačující, při detekci jízdy „něčeho“ na červenou je vytvořen sedmivteřinový segment videa na který je poté možné použít náročnější a přesnější metody detekce.

Kapitola 9

Závěr

Cílem této práce bylo řešení problému detekce průjezdu vozidla na červenou pro dohledové kamery pro potřeby policie a prevenci kriminalit, vzhledem k rozsahu silniční sítě je nutnou součástí řešení automatická kalibrace.

Během práce jsem prostudoval různé způsoby detekce semaforu a vozidel, vybrané algoritmy jsem popsal v kapitolách 3 a 4. V průběhu implementace jsem prováděl experimenty s jednotlivými metodami detekce a ty jsem dále vylepšoval, aby bylo dosaženo co nejlepších výsledků. Provedl jsem také konečné srovnání všech metod, které bylo popsáno v kapitole 7.

Výsledkem práce je program pro tuto detekci a experimentální porovnání šesti použitých detekčních metod pro semafor a vozidla. Jako nejúspěšnější se ukázala metoda detekce semaforu podle chování s naměřenou úspěšností 100% na použitém vzorku 100 testovacích záběrů.

Metody pro detekci aut jsou schopny detekovat většinu projíždějících vozidel, některá vozidla jedoucí blízko sebe ovšem detekují jako jedno.

Práce mi dala přehled o základních metodách používaných pro detekci statických i pohybujících se objektů ve videu.

Rozšíření práce může probíhat několika směry. Jednou z možností je experimentování s detekcí pomocí strojového učení, jako zajímavější se mi jeví implementace detekce poznávacích značek, optimalizace vybraných metod a tvorba vestavěného systému schopného provádět detekci v reálném čase.

Literatura

- [1] Zákon č. 361/2000 Sb., o provozu na pozemních komunikacích a o změnách někt. zákonů (zákon o silničním provozu). *Sbírka zákonů*, 2000.
- [2] Scikit-video [online]. <http://www.scikit-video.org/>, 2017, [cit. 2017-02-12].
- [3] Cheng-Chin, C.; Ming-Che, H.; Hong-Sheng, L.; aj.: Detecting and recognizing traffic lights by genetic approximate ellipse detection and spatial texture layouts [online]. *International Journal of Innovative Computing, Information and Control*, ročník 7, č. 12, 2011: s. 6919–6934.
URL <http://www.ijicic.org/ijicic-10-08060.pdf>
- [4] Cheung, S.-C. S.; Chandrika, K.: Robust techniques for background subtraction in urban traffic video [online]. *Visual Communications and Image Processing 2004*, ročník 5308, 2004: s. 881–892.
URL <http://dx.doi.org/10.1117/12.526886>
- [5] Chris, S.; L., G. W. E.: Adaptive background mixture models for real-time tracking [online]. *Computer Vision and Pattern Recognition, 1999. IEEE Computer Society Conference on.*, ročník 2, 1999: s. 246–252, doi:10.1109/CVPR.1999.784637.
URL <http://ieeexplore.ieee.org/abstract/document/784637/>
- [6] Christian, G.; Detlev, N.; Martin, W.: Artificial neural networks in real-time car detection and tracking applications [online]. *Pattern Recognition Letters*, ročník 17, č. 4, 1996: s. 335–343.
URL <http://www.sciencedirect.com/science/article/pii/0167865595001298>
- [7] Emmanuel, D. S. R.; Yohan, D.; Peggy, S.; aj.: A survey of vision-based traffic monitoring of road intersections [online]. *IEEE transactions on intelligent transportation systems*, ročník 17, 2016: s. 2681–2698, doi:10.1109/TITS.2016.2530146.
URL <http://ieeexplore.ieee.org/abstract/document/7458203/>
- [8] HS, A. A.; HC, Y. N.: A video-based system methodology for detecting red light runners [online]. 1998.
URL <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.145.1505>
- [9] Itseez: About OpenCV [online]. <http://opencv.org/about.html>, 2017, [cit. 2017-02-12].
- [10] J, L. A.; Hironobu, F.; S, P. R.: Moving target classification and tracking from real-time video [online]. *Applications of Computer Vision, 1998. WACV'98*.

- Proceedings., Fourth IEEE Workshop on*, 1998: s. 8–14,
doi:10.1109/ACV.1998.732851.
URL <http://ieeexplore.ieee.org/abstract/document/732851/>
- [11] Jie, Y.; Xiaomin, C.; Pengfei, G.; aj.: A new traffic light detection and recognition algorithm for electronic travel aid [online]. *Intelligent Control and Information Processing (ICICIP), 2013 Fourth International Conference on*, doi:10.1109/ICICIP.2013.6568153.
URL <http://ieeexplore.ieee.org/abstract/document/6568153/>
- [12] Masako, O.; Shinichiro, O.: Traffic light detection with color and edge information [online]. *Computer Science and Information Technology, 2009. ICCSIT 2009. 2nd IEEE International Conference on*, 2009: s. 284–287,
doi:10.1109/ICCSIT.2009.5234518.
URL <http://ieeexplore.ieee.org/abstract/document/5234518/>
- [13] V, J.; K, Y.; B, Q.; aj.: Traffic light recognition in varying illumination using deep learning and saliency map [online]. *Intelligent Transportation Systems (ITSC), 2014 IEEE 17th International Conference on*, 2014: s. 2286–2291,
doi:10.1109/ITSC.2014.6958056.
URL <http://ieeexplore.ieee.org/abstract/document/6958056/>
- [14] Viola, P.; Jones, M.: Rapid object detection using a boosted cascade of simple features [online]. *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, ročník 1, 2001: s. I–I,
doi:10.1109/CVPR.2001.990517.
URL <http://ieeexplore.ieee.org/abstract/document/990517/>
- [15] Žára, J.; Beneš, B.; Sochor, J.; aj.: *Moderní počítačová grafika*. Computer Press, 2004, ISBN 80-251-0454-0.

Přílohy

Příloha A

Obsah DVD

- Zdrojový kód bakalářské práce (.tex) a elektronická verze ve formátu PDF
- Program pro detekci jízdy na červenou
- Program pro porovnání metod detekce jízdy na červenou
- Vzorek testovacích videí
- Návod k použití programu
- Video demonstrující činnost programu

Příloha B

Vliv osvětlení na jednotlivé metody



Obrázek B.1: Detekce podle barev



Obrázek B.2: Detekce podle rámu



Obrázek B.3: Detekce podle tvaru



Obrázek B.4: Detekce podle chování